

ČLANCI

Učinak socioekonomskog statusa na obrazovno postignuće učenika: Primjer PISA istraživanja, Hrvatska 2006.

MARGARETA GREGUROVIĆ***SIMONA KUTI**

Institut za migracije i narodnosti

Zagreb, Hrvatska

Izvorni znanstveni rad

UDK: 371.26(497.5)

doi: 10.3935/rsp.v17i2.918

Primljeno: prosinac 2009.

Socioekonomski status pojedinca ima utjecaj na gotovo sve sfere njegova/ njezina života, uključujući i obrazovanje. Cilj je ovoga rada utvrditi i objasniti povezanost socioekonomskog statusa obitelji učenika i njihovog obrazovnog postignuća. Rad se temelji na OECD - PISA međunarodnom istraživanju provedenom u Hrvatskoj 2006. godine na uzorku od 5 209 petnaestogodišnjih učenika srednjih škola. U radu su korišteni ispitni rezultati učenika iz prirodoslovne pismenosti, kao i varijable i indeksi socioekonomskog statusa konstruirani od strane OECD-a. Prikazane su distribucije pojedinih varijabli vezanih uz utvrđivanje socioekonomskog statusa, kao što su obrazovanje roditelja, mjesečni prihodi kućanstva, novčana izdvajanja za obrazovne potrebe i obiteljski obrazovni resursi te njihove razlike s obzirom na hrvatske regije. Multiplom regresijskom analizom potvrđena je povezanost socioekonomskih indikatora s uspjehom učenika na ispitu iz prirodoslovlja. Prediktorski model sastavljen od tri indeksa (najviši međunarodni socioekonomski indeks zanimanja, indeks obiteljskih obrazovnih resursa i indeks posjedovanja kulturnih dobara) i četiri varijable (prosječni mjesečni prihodi kućanstva, prosječni mjesečni izdaci za obrazovanje, broj knjiga u kućanstvu i najviši stupanj obrazovanja roditelja) tumači 23% ukupne varijance postignuća iz prirodoslovne pismenosti. Drugi model s uključenom regijom stanovanja dodatno pridonosi za 1% upućujući na značajnu povezanost obitavanja u pojedinoj regiji s postignućem u prirodoslovlju. Zaključak je ovoga rada da je socioekonomski status (uz regionalnu pripadnost) značajan prediktor obrazovnog postignuća te je on važan faktor u analizama i interpretacijama ispitnih rezultata PISA istraživanja, iako bi za Hrvatsku bila potrebna adaptacija PISA indeksa kako bi oni vjerodostojnije predstavljali podatke. Preporučljiva je kontinuirana analiza ispitnih rezultata prikupljenih PISA istraživanjem u kojoj će se, uz neke općenite pokazatelje obrazovnog uspjeha, kao što su obrazovni sustav, kvalificiranost profesora i školska infrastruktura, u obzir uzimati i socioekonomski status učenika.

Ključne riječi: socioekonomski status, obrazovno postignuće, OECD PISA, Hrvatska, hrvatske regije.

* Margareta Gregurović, Institut za migracije i narodnosti/Institute for Migration and Ethnic Studies, Trg Stjepana Radića 3, 10 000 Zagreb, Hrvatska/Croatia, margareta.gregurovic@imin.hr

UVOD

Utjecaj socioekonomskog statusa (SES) na obrazovno postignuće tema je koja je inspirirala brojne znanstvene radove iz područja sociologije obrazovanja.¹ Već se u 40-im godinama (od Warnera i suradnika, 1944., Hollingsheada, 1949. do Coleman, 1961., citirano iz: DiMaggio, 1982.), a posebice od sredine 60-ih, istražuju različiti aspekti ove teme (Coleman i sur., 1966. u Rumberger i Palardy, 2005.; Sewell i Shah, 1967.; Sewell i sur., 1970.), a značajna povezanost SES-a s obrazovnim postignućem učenika vjerojatno je najrepliciraniji nalaz istraživanja (Davies, 1995.) i to ne isključivo u SAD-u, koje predvode u broju istraživanja, već i u drugim zemljama diljem svijeta (Matějů i Peschar, 1989.; Hatcher, 1998.; Driessen, 2001.). Polazeći od pretpostavke da su učenici nižeg SES-a u nepovoljnijem položaju prema ostalima, rezultati većine navedenih istraživanja između ostalog ukazuju na to da škole nemaju mehanizme kojima kompenziraju razlike prema SES-u kod učenika, a koje onda naposljetku određuju i njihov školski uspjeh (Arnett, 2004.) No ipak, prema rezultatima istraživanja, različite dimenzije obiteljskog SES-a učenika često su bolji prediktori obrazovnog postignuća od karakteristika škola (npr. školske infrastrukture, kvalitete profesora i sl.) (Heyneman, 1976.; Arnett, 2004.; Rumberger i Palardy, 2005.).

U Hrvatskoj su istraživanja povezanosti SES-a i obrazovnih ishoda većinom bila postavljena u obrnutom smjeru, tj. socioekonomski status pojedinca objašnjavao se pomoću stečenog stupnja obrazovanja (Nestić, 2002.; Karaman Aksentijević i sur., 2006.). Usmjerenost na mogućnosti analiziranja i objašnjavanja obrazovnih rezultata s aspekta SES-a praktički nije potaknuta

niti dostupnošću podataka međunarodnih istraživanja, no ipak postoje istraživanja na lokalnoj razini koja se bave tom tematikom (Pavić i Vukelić, 2009.).

Ovim se radom nastoji ispitati kakva je povezanost pokazatelja socioekonomskog statusa s ispitnim rezultatima hrvatskih učenika, a koji su dobiveni OEDC - PISA istraživanjem u 2006. godini kada je naglasak istraživanja bio na prirodoslovnoj pismenosti. Već je u ranijim radovima ustanovljena povezanost socioekonomskog statusa općenito s rezultatima iz fizike, kemije i/ili biologije (Yildirim i Eryilmaz, 1999.; Young i Fraser, 1993.; Burstein i sur., 1980.) upućujući na pozitivnu vezu između višeg socioekonomskog statusa obitelji i višeg postignuća učenika u prirodoslovnim znanostima. Iako su u navedenim istraživanjima korišteni različiti indikatori socioekonomskog statusa, poput zanimanja roditelja, obrazovanja roditelja i veličine obitelji (Young i Fraser, 1993.), obrazovnog stupnja majke, broja knjiga u kućanstvu, zanimanja roditelja i veličine obitelji (Young, 1995.), obrazovnog stupnja oca i broja knjiga u kućanstvu (Burstein i sur., 1980.) u ovom će se radu socioekonomski status opisati pomoću indeksa i varijabli definiranih te prikupljenih PISA istraživanjem, a koje uključuju obrazovni stupanj roditelja, zanimanje roditelja, prihode kućanstva, mjesečne izdatke za obrazovanje te posjedovanje različitih uvjeta, sredstava i pomagala koja bi mogla stvoriti povoljnu okolinu za učenje.

Polazeći od pretpostavke da postoji značajna povezanost SES-a učenika i njihovih ispitnih rezultata iz prirodoslovlja, u radu će se dati pregled i deskripcija socioekonomskih indeksa i varijabli koje su korištene u PISA istraživanju, analizirat će se njihova povezanost s ispitnim rezultatima te će se uputiti na neke od važnih

¹ Uz radove Bourdieua i Boudona, značajna su još i istraživanja Sewella, DiMaggia, Daviesa, »Colemanov izvještaj«, itd.

faktora koje treba uzeti u obzir prilikom formuliranja i kreiranja potencijalnih mehanizma oblikovanja obrazovnog sustava u Hrvatskoj s posebnim naglaskom na socijalnu osjetljivost. Imajući u vidu geografsko-kulturne različitosti unutar same Hrvatske, a isto tako i dokazane razlike prema socioekonomskom statusu između regija (Japćić i Šućur, 2007.) te njihove razlike prema razini bruto društvenog proizvoda (Državni zavod za statistiku, 2009.), neke od analiza usmjerit će se na detaljnije objašnjavanje regionalnih razlika koje će se uzeti u obzir pri objašnjavanju pojedinih aspekata povezanosti SES-a i postignuća u prirodoslovlju.

PISA ISTRAŽIVANJE

OECD PISA ((OECD's) Programme for International Student Assessment), tj. Program za međunarodnu procjenu učenika jedno je od najvećih međunarodnih istraživanja obrazovanja čija je glavna namjena prikupljanje i pružanje, kreatorima obrazovnih politika zemalja sudionica, međunarodno usporedivih podataka o obrazovnim postignućima učenika te podataka o institucionalnim, obiteljskim i učeničkim faktorima koji mogu pomoći u objašnjenju razlika u postignuću. PISA mjeri različite dimenzije pismenosti i znanja, kao i sposobnost primjenjivanja tog znanja u svakodnevnim situacijama, što odgovara konceptu cjeloživotnog učenja. Iz tog razloga PISA nije isključivo procjena znanja stečenog tijekom prethodne školske godine, već procjena znanja i vještina akumuliranih od samog rođenja (Willms, 2006.; OECD, 2007.).

Prvo PISA istraživanje provedeno je 2000. godine, a svaki ciklus u trajanju od 3 godine uključuje probno istraživanje, glav-

no istraživanje, obradu podataka i publikaciju rezultata te izvještavanje o postignutim rezultatima. Republika Hrvatska uključila se u PISA istraživanje prvi put u ciklusu 2006., a sudjelovala je i u ciklusu 2009.

Budući da se u radu koriste rezultati iz ciklusa PISA 2006., obrazovno postignuće bit će prikazano kroz rezultate prirodoslovne pismenosti² koja se u okviru PISA-e odnosi na posjedovanje i primjenu znanja iz prirodoslovne grupe predmeta te njihovo razumijevanje i promišljanje (OECD, 2007.; usp. Braš Roth i sur., 2008.). Iz tog su razloga ispitna pitanja konstruirana na način da se od učenika očekuje analiziranje, logičko zaključivanje te snalaženje u postavljanju, rješavanju i interpretiranju problema u različitim životnim situacijama.

PISA istraživanjem prikupljeni su i detaljni sociodemografski podaci na temelju kojih je bilo moguće istražiti povezanost socioekonomskog statusa učenika s njihovim postignućem u školi. Sociodemografski podaci dobiveni su kroz tri dodatna upitnika: upitnik za učenike, upitnik za roditelje i upitnik za školu, a mjereni su kroz pitanja o učenikovoj obitelji (npr. zaposlenju i stručnoj spremi roditelja, imovinskom statusu, etničkom podrijetlu članova uže obitelji itd.). Svrha korištenja ovih upitnika je prikupljanje važnih kontekstualnih informacija koje se koriste pri interpretaciji i analizi ispitnih rezultata učenika u izvještajima PISA istraživanja.

Opis analiziranih instrumenata PISA istraživanja

Ispit prirodoslovne pismenosti

Postignuće u prirodoslovnoj pismenosti mjereno je kroz 114 ispitnih pitanja grupiranih u 38 cjelina. Teme cjelina bile su

² U PISA istraživanju procjenjuju se 3 područja: čitalačka, matematička i prirodoslovna pismenost, no u svakom je ciklusu naglasak na jednoj od njih, dok ciklus dobiva ime prema godini u kojoj se provodi glavno istraživanje. U ciklusu PISA 2000. glavno je područje procjene bila čitalačka pismenost, u ciklusu 2003. matematička pismenost, a u ciklusu 2006. prirodoslovna pismenost. U ciklusu 2009. bila je ponovno procjenjivana čitalačka pismenost. (OECD, 2007.; Braš Roth i sur., 2008.).

primjerice kisele kiše, staklenici, zaštita od sunca, genetski modificirani usjevi i tome slično. Uz uvodni tekst u kojem se opisivala određena tematika, svaka cjelina sadržavala je u prosjeku 3 pitanja. Ovakva konstrukcija pitanja omogućila je generiranje skale postignuća prema kojoj je svakom ispitanom pitanju dodijeljen određen broj bodova prema njegovoj težini te je sukladno tome svakom učeniku dodijeljen broj bodova koji prikazuje njegove/njezine procijenjene sposobnosti. Skala postignuća konstruirana je pomoću teorije odgovora na zadatak (*Item Response Theory* – IRT) (Magno, 2009.; Muis i sur., 2009.).³

Indeksi i varijable socioekonomskog statusa

Socioekonomski status mjereno je u PISA istraživanju kroz pitanja iz upitnika za učenike u kojima se pitalo o obrazovanju i vrsti zaposlenja roditelja te o posjedovanju različitih materijalnih dobara. Budući da se odgovori petnaestogodišnjaka općenito smatraju dovoljno pouzdanima za procjenu stupnja obrazovanja i zaposlenja roditelja (usp. Merola, 2005.; Thorpe, 2006.),⁴ na temelju ovih varijabli kreirano je nekoliko indeksa socioekonomskog statusa.⁵ S druge strane, roditelji su odgovarali na pitanja o vlastitom obrazovanju i zaposlenju, o obiteljskom prihodu i mjesečnim izdacima za obrazovanje koja su u radu korištena kao opći i deskriptivni pokazatelji socioekonomskog statusa te potencijalni prediktori obrazovnog uspjeha. U nastavku je naveden kratak opis indeksa utemeljenih na odgo-

vorima učenika, a koji se koriste u daljnjim analizama:

1. Najviši međunarodni socioekonomski indeks zanimanja kreiran je na temelju učeničkih odgovora na otvoreno pitanje o zanimanju roditelja. Indeks je inačica međunarodnog socioekonomskog indeksa zanimanja (International socioeconomic index (ISEI) of occupational status) koji su kreirali Ganzeboom i suradnici (1992.). Metodologija konstrukcije indeksa usmjerena je na dimenzioniranje zanimanja koje optimalno objašnjava povezanost obrazovanja i prihoda (Ganzeboom i sur., 1992.). Indeksom se preko karakteristika zaposlenja (profesije roditelja) stupanj obrazovanja pretvara u prihod⁶. Indeks je kreiran optimalnim skaliranjem skupina profesija u svrhu maksimiziranja indirektnog utjecaja obrazovanja na prihode (kroz vrstu zaposlenja), a minimiziranja direktnog utjecaja obrazovanja na prihode (Ganzeboom i Treiman, 1996.:212). Pri kreiranju indeksa ključni su koeficijenti oni koji povezuju status profesije s obrazovanjem i s prihodom. Indeks se temelji na zaposlenju koje je više rangirano, bez obzira je li to zaposlenje oca ili majke, a više vrijednosti indeksa upućuju na viši stupanj statusa zaposlenja.

2. Indeks obiteljskih obrazovnih resursa kreiran je putem teorije odgovora na zadatak, a na temelju učeničkih podataka o dostupnosti sljedećih stvari u kućanstvu: a) vlastitog radnog stola, b) tihog kutka

³ *Item response theory* – teorija odgovora na zadatak povezuje karakteristike zadatka (parametre zadatka) i karakteristike pojedinca (latentne osobine) s vjerojatnošću davanja točnog odgovora. Prema ovom pristupu svako ispitno pitanje prikazuje se kroz njegovu karakterističnu krivulju koja opisuje vjerojatnost točnog ili netočnog odgovora na to pitanje s obzirom na sposobnost ispitanika (Magno, 2009.).

⁴ U okviru PISA istraživanja ustanovljena je visoka podudarnost između učeničkih i roditeljskih odgovora.

⁵ Drugi od razloga za korištenje upravo odgovora učenika je taj što u većini zemalja upitnik za roditelje nije upotrebljavan (OECD, 2007.).

⁶ Prema međunarodno standardiziranoj klasifikaciji zanimanja ISCO 1988. (*International Standard Classification of Occupations*).

za učenje, c) računala koje učenici mogu koristiti za izvršavanje školskih zadataka, d) obrazovnih računalnih programa, e) vlastitog kalkulatora, f) udžbenikâ i g) rječnikâ. Pozitivnije vrijednosti indeksa predstavljaju i veću zastupljenost obiteljskih obrazovnih resursa.

3. Indeks posjedovanja kulturnih dobara kreiran je na isti način kao i prethodni te je sastavljen od 3 varijable: posjedovanje djela klasične književnosti, zbirke poezije te umjetničkih djela. Više vrijednosti ukazuju na veći stupanj posjedovanja kulturnih dobara.⁷

U radu se neće isključivo koristiti kreirani PISA indeksi, već će se u analize kao prediktori uvrstiti i dodatne varijable SES-a (prosječni mjesečni prihod kućanstva, prosječni mjesečni izdaci za obrazovanje, najviši stupanj obrazovanja roditelja, broj knjiga u kućanstvu). U potencijalnim daljnjim istraživanjima preporučljiva je dodatna provjera konstrukcije svih indeksa na hrvatskome uzorku te njihova prilagodba kako bi vjerodostojnije i pouzdanije opisivali podatke dobivene PISA istraživanjem.

METODOLOGIJA

S obzirom da je jedan od glavnih ciljeva PISA istraživanja utvrđivanje pripremljenosti učenika za ulazak u svijet odraslih te za nastavak obrazovanja ili uključivanje u proces rada, odabrana je dob od 15 godina

jer se u većini zemalja sudionica učenici u toj dobi bliže kraju obaveznog obrazovanja pa se procjenom može dobiti uvid u njihovo znanje, vještine i stavove akumulirane tijekom razdoblja od otprilike deset godina školovanja.

U ciklusu PISA 2006. sudjelovalo je 57 zemalja, od čega ih je 30 bilo članica OECD-a i 27 partnerskih zemalja, što je jedan od razloga zbog kojeg se PISA smatra jednim od najvećih međunarodnih istraživanja obrazovnih postignuća.⁸ Testirano je gotovo 400 000 učenika koji reprezentiraju oko 20 milijuna petnaestogodišnjaka iz zemalja sudionica. U većini zemalja procjenjivanje se provodi na uzorku od približno 4 500 do 10 000 učenika.

U Hrvatskoj je PISA istraživanje provedeno u 159 srednjih i 9 osnovnih škola⁹, s time da su osnovne škole isključene iz daljnjih obrada zbog premalog broja učenika. Škole su odabrane s obzirom na dominantni program i veličinu mjesta u kojem se nalaze. Iz odabranih škola prikupili su se popisi svih petnaestogodišnjih učenika, iz kojih se onda slučajnim uzorkovanjem odabralo po 35 učenika iz svake škole. Testiranju je pristupilo 5 242 učenika od čega 5 209 srednjoškolaca na čijim je odgovorima vršena analiza.¹⁰ Uzorak je reprezentativan za populaciju hrvatskih petnaestogodišnjaka s obzirom na spol, tip školskog programa te razred.¹¹

Budući da je u radu naglasak na ispitivanju povezanosti socioekonomskog statu-

⁷ Pouzdanost indeksa posjedovanja kulturnih dobara na hrvatskom uzorku izražena Cronbachovom alforom iznosi 0,65, a indeksa obiteljskih obrazovnih resursa 0,44.

⁸ Iako su PISA-u osmislile članice OECD-a, u samom istraživanju sudjeluju i druge zemlje kao partneri. U prvom ciklusu sudjelovale su ukupno 43 zemlje, u drugom 41, u trećem ciklusu 57 zemalja, a u ciklusu PISA 2009. 65 zemalja.

⁹ PISA istraživanje u Hrvatskoj proveo je PISA centar u sklopu Nacionalnog centra za vanjsko vrednovanje obrazovanja.

¹⁰ Općenita stopa odaziva iznosi 93%. Od učenika koji su pristupili testiranju, 92% roditelja pristalo je ispuniti upitnik, što je vrlo veliki odaziv u usporedbi s ostalim zemljama sudionicama (Braš Roth i sur., 2008.; OECD, 2007.).

¹¹ Udio muških ispitanika u uzorku iznosi 50,1%, udio gimnazijalaca je 27,1%, udio učenika četverogodišnjih srednjih škola je 45% te udio učenika prvih razreda srednje škole iznosi 77,7%.

sa i ispitnih rezultata, u tu svrhu korištena je (multipla) linearna regresijska analiza u kojoj su prediktorske varijable ranije opisani pokazatelji socioekonomskog statusa, a ispitni rezultat iz prirodoslovlja kriterijska varijabla.

Uz analizu rezultata na razini cijele države, u radu su ispitane i razlike u PISA rezultatima na regionalnoj razini Hrvatske. U radu je korištena službena statistička NUTS-2 regionalna podjela, prema kojoj se Hrvatska može podijeliti na sljedeće tri regije: Sjeverozapadna Hrvatska, Središnja i Istočna (Panonska) Hrvatska te Jadranska Hrvatska. U analizama je korištena podjela na regije, a ne županije iz razloga što distribucija uzorkovanih škola po županijama nije bila ravnomjerna. Velike razlike u broju učenika u županijama znatno bi otežale analize jer se ne radi o približno jednakim grupama, a i pouzdanost tih analiza bila bi manja. S druge strane, regionalna raspodjela prema kriterijima EU-a za izradu statističkih jedinica na razini NUTS-2 uvodi, do određene razine, komparabilnije jedinice prema broju stanovnika, homogenosti statističkih jedinica, prirodno-geografskoj raznolikosti i povijesnoj tradiciji (Lovrinčević i sur., 2005.). U slučaju podjele na tri regije, iako je broj škola relativno disproporcionalan, omjer učenika je približno sličan (34% : 30% : 36%). Razlike između hrvatskih regija provjerene su pomoću analize varijance, a u okviru multiple linearne regresijske analize, varijabla regije testirana je kao jedna od prediktorskih varijabli.

REZULTATI I RASPRAVA

U prosincu 2007. godine službeno su objavljeni rezultati ciklusa PISA 2006. te su tom prilikom podaci postali dostupni široj znanstvenoj populaciji i javnosti. U nastavku rada prvo će se dati pregled ispitnih

rezultata koje su, u području prirodoslovne pismenosti, postigli hrvatski učenici, a koji će se u regresijskoj analizi koristiti kao kriterijska varijabla. Slijedi kratak deskriptivni prikaz skupa prediktorskih varijabli koji se sastoji od tri indeksa i četiri varijable te analiza regresijskih modela koji opisuju povezanost indikatora socioekonomskog statusa i stanovanja u određenoj regiji s postignutim rezultatima.

Rezultati hrvatskih učenika u području prirodoslovne pismenosti

Prema službenim rezultatima OECD PISA istraživanja Hrvatska je s prosječnim rezultatom od 493 boda u prirodoslovnoj pismenosti postigla rezultat statistički značajno niži od prosjeka članica OECD-a. S takvim se ukupnim rezultatom Hrvatska smjestila na 26. mjesto od 57 zemalja sudionica (OECD, 2007.; Braš Roth i sur., 2008.). Poredak rezultata sudionica PISA-e sastavljen je s obzirom na statističku značajnost razlike od prosjeka članica OECD-a koji je standardiziran i iznosi 500, a standardna devijacija iznosi 100. Na taj je način rezultat oko dvije-trećine učenika iz zemalja OECD-a bio pozicioniran između 400 i 600 bodova.

Važno je istaknuti da su objavljeni rezultati raspoređeni s obzirom na OECD-ov konstruirani prosjek, dok bi se prema prosjeku svih zemalja (473,14 iz područja prirodoslovlja) rezultat hrvatskih učenika smjestio iznad prosjeka. Iako su se gotovo po prvi puta susreli s ovakvim načinom ispitivanja i provjere stečenih znanja i s obzirom na činjenicu da u hrvatskom obrazovnom sustavu ne postoji prirodoslovlje kao jedinstveni predmet, hrvatski učenici postigli su vrlo dobre rezultate bez obzira što su oni statistički značajno niži od prosjeka OECD-a.

Tablica 1.

Prosječni rezultat prirodoslovne pismenosti u Republici Hrvatskoj i regijama RH

	Broj ispitanika	Prosječni broj bodova (M)	Standardna devijacija (σ)
Hrvatska	5 209	493	86
Sjeverozapadna Hrvatska	1 766	508	82
Jadranska Hrvatska	1 894	489	82
Središnja i Istočna Hrvatska	1 548	483	80

Na razini rezultata regija RH, učenici iz Sjeverozapadne Hrvatske postigli su najbolji rezultat iz prirodoslovne pismenosti ($M=508$, $\sigma=82$), koji je bolji od prosjeka članica OECD-a i ukupnog hrvatskog prosjeka (tablica 1.). Prosječni rezultati ostalih dviju regija međusobno su prilično slični. Učenici Središnje i Istočne Hrvatske postigli su u prosjeku 483 boda ($\sigma=80$), a učenici Jadranske Hrvatske 489 bodova ($\sigma=82$). Objašnjenje za ovakve rezultate može se potražiti u regionalnoj distribuciji srednjih škola budući da se u Zagrebu, koji pripada Sjeverozapadnoj Hrvatskoj, nalazi gotovo 20% svih srednjih škola RH. Zagrebačke škole vjerojatno su mnogo opremljenije za izvođenje nastave iz prirodoslovne grupe predmeta, veći je stupanj informatizacije,

a učenici na raspolaganju imaju više škola (poglavito gimnazija) i učeničkih domova, nego što je to u drugim gradovima i mjestima.

Indikatori socioekonomskog statusa

Indeksi socioekonomskog statusa

U PISA istraživanju korišteno je nekoliko različitih indeksa socioekonomskog statusa, no u ovom radu koristit će se tri indeksa koji su najuže definirani.¹² U tablici 2. nalazi se deskriptivan prikaz indeksa korištenih u ovom radu, odnosno najvišeg međunarodnog socioekonomskog indeksa zanimanja, indeksa obiteljskih obrazovnih resursa i indeksa posjedovanja kulturnih dobara.

Tablica 2.

Deskriptivni prikaz indeksa socioekonomskog statusa na hrvatskom uzorku

	Ukupno		Sjeverozapadna Hrvatska		Središnja i Istočna Hrvatska		Jadranska Hrvatska	
	M	σ	M	σ	M	σ	M	σ
Najviši međunarodni socio-ekonomski indeks zanimanja	46,94	15,08	47,95	15,38	44,11	14,39	47,49	15,12
Indeks obiteljskih obrazovnih resursa	0,01	0,91	0,07	0,90	-0,07	0,93	-0,03	0,91
Indeks posjedovanja kulturnih dobara	-0,20	0,94	-0,10	0,93	-0,38	0,93	-0,19	0,93

¹² U PISA istraživanju korišteni su još i sljedeći indeksi: Index of economic, social and cultural status, Index of home possessions, Family wealth (OECD, 2007.).

Svi prikazani indeksi po prosjeku se razlikuju od članica OECD-a. Najviši međunarodni socioekonomski indeks zanimanja u Hrvatskoj prosječno ima vrijednost 46,94 dok je na razini OECD-a njegova prosječna vrijednost nešto viša ($M=48,8$, $\sigma_M=0,17$). Gledano po hrvatskim regijama prosjek navedenog indeksa u Središnjoj i Istočnoj Hrvatskoj niži je od njegova prosjeka u druge dvije regije. Ista situacija ponavlja se i kod druga dva indeksa koji su također (promatrano na razini cijele Hrvatske) u prosjeku niži od prosjeka članica OECD-a prema kojem prosjek indeksa obrazovnih resursa iznosi 2,67, $\sigma=1,52$, a prosjek indeksa posjedovanja kulturnih dobara 0,30, $\sigma=1,64$ (OECD, 2009.).

Tablica 3.

Deskriptivni prikaz varijabli socioekonomskog statusa

	Ukupno		Sjeverozapadna Hrvatska		Središnja i Istočna Hrvatska		Jadranska Hrvatska		Razlike između regija	
	M	σ	M	σ	M	σ	M	σ	F	p
Najviši stupanj obrazovanja roditelja	2,27	0,62	2,29	0,62	2,15	0,64	2,34	0,60	41,18	0,000
OŠ i manje	9,6%		8,6%		13,9%		7,1%			
Srednja škola	53,9%		53,3%		57,0%		51,9%		2≠1	
Viša škola i više	36,5%		38,1%		29,1%		41,0%		2≠3	
Prosječni mjesečni prihodi kućanstva	1,90	0,63	2,02	0,62	1,69	0,62	1,97	0,60	123,38	0,000
Manje od 4 000 kn	25,0%		18,3%		38,9%		19,3%			
4 000-10 000 kn	59,8%		61,6%		52,8%		64,2%		2≠1	
10 000 kn ili više	15,2%		20,1%		8,3%		16,5%		2≠3	
Prosječni mjesečni izdaci za obrazovanje	1,57	0,70	1,62	0,71	1,53	0,70	1,56	0,70	7,25	0,001
Manje od 150 kn	55,1%		50,7%		58,9%		56,0%			
150-400 kn	32,4%		36,1%		29,2%		31,5%		1≠2	
400 kn ili više	12,6%		13,2%		12,0%		12,5%		1≠3	
Broj knjiga u kućanstvu	2,41	1,06	2,51	1,06	2,17	1,02	2,51	1,06	55,70	0,000
0-10	25,4%		22,1%		32,7%		22,5%			
11-25	26,6%		25,9%		29,5%		24,9%		2≠1	
26-100	29,6%		30,8%		25,6%		31,8%		2≠3	
Više od 100	18,4%		21,2%		12,2%		20,7%			

¹³ Iako su pitanja o najvišem postignutom stupnju obrazovanja roditelja bila uključena u oba upitnika, ovom prilikom koriste se iskazi roditelja. U slučaju da je iskaz ili upitnik roditelja nedostajao (oko 10%) koristio se odgovor učenika o obrazovnim statusu roditelja.

Obrazovanje roditelja prikazano je kroz najviši postignuti stupanj obrazovanja među roditeljima. Distribucija varijable pokazuje konzistentnost s posljednjim popisom stanovništva i drugim istraživanjima (Japec i Šućur, 2007.; Fahey, 2004.) upućujući na najvišu zastupljenost roditelja sa srednjoškolskim obrazovanjem (oko 55%) i na razini cijele Hrvatske i njenih regija. Važno je istaknuti da je udio roditelja s višim ili visokim obrazovanjem u ovom slučaju izraženiji nego u drugim istraživanjima (usp. Matković, 2010.), što se vjerojatno može pripisati selektivnom neodgovaranju na pitanje ili pak »poboljšanoj samoprezentaciji« roditelja.

Distribucija prosječnih mjesečnih prihoda kućanstva pokazuje da najveći udio ispitanika (oko 60%) ima mjesečne prihode između 4 000 i 10 000 kuna što bi odgovaralo iznosu dvije prosječne plaće prema podacima Državnog zavoda za statistiku (2007.) prema kojima je iznos prosječne plaće u Hrvatskoj u 2006. godini bio oko 4 500 kuna. Statistički značajno prosječno najniže mjesečne prihode kućanstva imaju ispitanici iz Središnje i Istočne Hrvatske (usp. Botrić, 2007.; Nestić, 2002.; Šundalić, 2006., 2009.).

Mjesečna izdvajanja obitelji za obrazovanje, pod kojima se podrazumijevalo plaćanje školarine školskoj ustanovi koju dijete pohađa, plaćanje satova poduke u školi ili izvan nje i plaćanje raznih tečajeva za poduku ili pripremu učenika, u više od 80% obitelji ne prelaze 400 kuna.

Kao što je već ranije navedeno, broj knjiga u kućanstvu također se može koristiti kao indikator SES-a. Iz tablice 3. vidljivo je da u više od 50% kućanstava učenici navode da posjeduju do 25 knjiga. U Središnjoj i Istočnoj Hrvatskoj koja se statistički značajno razlikuje od druge dvije regije taj udio je još izraženiji te iznosi preko 60%.

Multipla regresijska analiza socioekonomskog statusa i obrazovnog postignuća

Kako bi se što bolje objasnila povezanost indikatora SES-a s postignućem iz prirodoslovne pismenosti, korištena je multipla linearna regresijska analiza s učeničkim rezultatom kao kriterijskom varijablom i pokazateljima SES-a kao prediktorskim varijablama. Kao prediktorske varijable korišteni su sljedeći indeksi i varijable: indeks posjedovanja kulturnih dobara (zbirke poezije, književnost, umjetnička djela), indeks obiteljskih obrazovnih resursa, indeks najvišeg međunarodnog socioekonomskog statusa zaposlenja, broj knjiga u kućanstvu, prosječni mjesečni prihodi kućanstva, prosječni mjesečni izdaci za obrazovanje, te najviši stupanj obrazovanja roditelja.

Regresijski model (tablica 4.) prikazuje prediktore učeničkog postignuća iz prirodoslovlja koji zajedno tumače 23% varijance kriterijske varijable. Prema tome, može se zaključiti da bolje rezultate iz prirodoslovne pismenosti postižu učenici čiji roditelji imaju više rangirano zaposlenje, čije obitelji posjeduju više obrazovnih resursa, knjiga i kulturnih dobara, učenici iz obitelji s višim mjesečnim prihodom kućanstva i manjim izdacima za obrazovanje te iz obitelji u kojima barem jedan od roditelja ima završenu srednju školu.

Najveće beta-pondere u modelu imaju broj knjiga u kućanstvu i najviši međunarodni socioekonomski indeks zaposlenja. Kao što se može vidjeti u tablici 4., učenici iz obitelji koje posjeduju više od 11 knjiga postižu bolje rezultate u prirodoslovlju od učenika iz kućanstava koja posjeduju do 10 knjiga. Posebno velika razlika u postignuću vidljiva je u slučaju posjedovanja više od 100 knjiga u kućanstvu ($\beta = 0,220$, $p < 0,001$). Broj knjiga u kućanstvu često se pojavljuje kao značajan prediktor obrazovnog uspjeha i u stranim istraživanjima (Young, 1995.; Burstein i sur., 1980.), vrlo često i nezavisno od ostalih faktora kao

Tablica 4.

Multipla regresija socioekonomskih indikatora (prediktori) i učeničkog rezultata iz prirodoslovlja (kriterij)

	Nestandardizirani koeficijenti		Standardizirani koeficijenti	Sig.	Korelacija	
	B	SE	Beta		direktna	parcijalna
(Konstanta)	450,244	4,748		0,000		
Najviši međunarodni socioekonomski indeks zanimanja	0,854	0,089	0,161	0,000	0,343	0,146
Indeks obiteljskih obrazovnih resursa	9,006	1,272	0,102	0,000	0,245	0,107
Indeks posjedovanja kulturnih dobara	7,694	1,400	0,090	0,000	0,312	0,084
Broj knjiga u kućanstvu: 11 - 25	13,254	3,159	0,073	0,000	-0,096	0,064
Broj knjiga u kućanstvu: 26 - 100	30,673	3,303	0,177	0,000	0,129	0,140
Broj knjiga u kućanstvu: više od 100	43,714	4,083	0,216	0,000	0,272	0,161
Prosječni mjesečni prihod kućanstva manji od 4 000 kn	-16,383	2,749	-0,086	0,000	-0,236	-0,091
Prosječni mjesečni prihod kućanstva veći od 10 000 kn	14,855	3,253	0,068	0,000	0,224	0,070
Prosječni mjesečni izdaci za obrazovanje 150-400 kn	-12,174	2,374	-0,071	0,000	-0,037	-0,078
Prosječni mjesečni izdaci za obrazovanje veći od 400 kn	-20,534	3,400	-0,084	0,000	-0,066	-0,092
Najviše obrazovanje roditelja – OŠ ili manje	-8,774	4,077	-0,031	0,031	-0,171	-0,033
Najviše obrazovanje roditelja – Viša škola ili više	-2,398	2,558	-0,014	0,348	0,179	-0,014

$$R^2=0,230; F=106,529 (p<0,001)$$

što je npr. obrazovanje roditelja, pa autori i analitičari tih istraživanja zaključuju da bi jedna tehnološki i financijski manje zahtjevna mjera pribavljanja knjiga, posebno u kućanstvima određenih manjina u Sjedinjenim Američkim Državama, mogla imati pozitivan i značajan utjecaj na ujednačavanje obrazovnog uspjeha (Thoreson, 2004.:22). Isto tako, broj knjiga u kućanstvu ne predstavlja samo pokazatelj čitalačkih navika roditelja (eng. *parental reading behaviour*), već odražava i intelektualno okruženje u kućanstvu, koje uključuje raspon roditeljskih stavova i ponašanja koji mogu pogodovati školskim dostignućima (Marks, 2005.:17).

Drugi po redu prediktor je najviši međunarodni socioekonomski indeks zaposlenja koji se može interpretirati i kao indikator obrazovanja, profesije i prihoda roditelja i kao takav vjerojatno bolje reprezentira obiteljski SES. Pozitivna povezanost SES-a s obrazovnim postignućem

u stranim se istraživanjima interpretira na prilično sličan način. Tako prema Strakovoj (2007.), obrazovaniji roditelji više cijene i razumiju obrazovni sustav pa tako mogu dati dobre savjete i ohrabrenje svojoj djeci, dok djeca iz obitelji s nižim SES-om imaju manje poticaja u obitelji. Isto tako roditelji višeg SES-a više su angažirani oko školskih zadataka i aktivnosti svoje djece (Attewell i Battle, 1999.). Prema Fram i suradnicima (2007.:312) roditelji predstavljaju učinak resursa na učenje svoje djece, tj. oni prenose svoje znanje, ulažu vrijeme i energiju, pribavljaju materijalna dobra i stvaraju mogućnosti koje mogu pozitivno utjecati na razvoj djeteta. Ukoliko su roditelji obrazovaniji, ako imaju više životnog iskustva i više ekonomskih resursa, mogu pozitivnije utjecati na obrazovni uspjeh djeteta (Fram i sur., 2007.). S druge strane, iako u prosječnom kućanstvu niskog SES-a djeci često nedostaju bitni obrazovni

resursi, ukoliko su djeca iz takvih obitelji izložena emotivno poticajnom obiteljskom okruženju u kojem se potiče obrazovni uspjeh, i njihovi se rezultati značajno poboljšavaju (Okpala i sur., 2001.).

Značajnost indeksa obiteljskih obrazovnih resursa i indeksa posjedovanja kulturnih dobara također upućuje na pozitivnu povezanost različitih dobara poput udžbenika, književnih djela, raznih obrazovnih pomagala i tome slično s boljim ispitnim rezultatima. Navedeni su indeksi očekivano statistički značajno povezani s prosječnim mjesečnim prihodom kućanstva koji ujedno predstavlja osnovicu za nabavljanje navedenih dobara, iako u ovom slučaju i obrazovni status roditelja igra veliku ulogu u odlučivanju o nabavi navedenih dobara. Što se tiče povezanosti samih prihoda kućanstva i uspjeha na ispitu, također su dobiveni očekivani rezultati. U odnosu na učenike iz obitelji s prosječnim mjesečnim prihodima između 4 000 i 10 000 kuna oni učenici koji dolaze iz obitelji s prihodima manjim od 4 000 kuna postižu lošije rezultate, dok učenici iz obitelji s prosječnim prihodima iznad 10 000 kuna postižu značajno bolje rezultate u prirodoslovlju. Nasuprot tome, važno je istaknuti da je visina prosječnih mjesečnih izdataka za obrazovanje negativno vezana uz ispitne rezultate što upućuje na, naizgled kontradiktoran, zaključak da učenici u čije se obrazovanje »manje ulaže« postižu bolje rezultate iz prirodoslovlja. Prema podacima u tablici 4. vidljivo je da učenici iz obitelji koje ulažu više od 150 kuna mjesečno u obrazovanje postižu statistički značajno lošije rezultate od učenika čiji roditelji ulažu manje od 150 kuna mjesečno, no prilikom interpretacije treba imati na umu definiciju izdataka za obrazovanje koji se u PISA istraživanju prvenstveno odnose na plaćanje dodatne poduke iz određenih predmeta, tečajeva i priprema. Prema tome, može se zaključiti da učenici kojima nije potrebna dodatna

poduka i instrukcije iz prirodoslovne grupe predmeta postižu i bolje rezultate. Još je jedan aspekt mjesečnih izdataka važno istaknuti, a to je njihova distribucija s obzirom na mjesečne prihode kućanstva. Potrebno bi bilo kreirati poseban indeks mjesečnih izdataka za obrazovanje s obzirom na mjesečne prihode kućanstva, ali i na broj djece u pojedinom kućanstvu. Na taj način dobio bi se uvid u to da zapravo, iako većina ulaže slične iznose u obrazovanje (što se može povezati i s jedinstvenim cijenama instrukcija), nemaju svi iste prihode, odnosno imaju, s druge strane, više ili manje djece, pa prihodi kućanstva koji odlaze na obrazovanje nisu isti. Prema tome bi se moglo više vrednovati ulaganje »siromašnijih« roditelja u usporedbi s istim iznosima ulaganja bogatijih te bi se na takav način mogla ispitati i motivacija roditelja za ulaganje u obrazovanje.

Najviši stupanj obrazovanja roditelja, iako statistički značajan, najmanje pridonosi tumačenju učeničkog postignuća. Rezultati pokazuju statistički značajnu razliku između postignuća učenika čiji roditelji imaju završenu osnovnu školu i učenika s roditeljima srednje stručne spreme upućujući da učenici roditelja sa završenom srednjom školom postižu bolje rezultate u prirodoslovlju. Indirektan utjecaj obrazovanja roditelja također se, do određene mjere, može pripisati i korištenim indeksima u modelu.

Budući da se radom pokušavaju utvrditi i regionalne razlike u postignuću u prirodoslovlju, kreirana su još dva regresijska modela. Prvim modelom (tablica 5.) utvrđen je udio varijance postignuća učenika u prirodoslovnoj pismenosti kojeg regije samostalno tumače, a koji iznosi nešto ispod 2%. Drugi model okupio je u prediktorskoj strukturi sve indikatore socioekonomskog statusa i regiju stanovanja u svrhu ispitivanja potencijalnih promjena utjecaja regije na postignuće učenika.

Tablica 5.

Multipla regresija s regijom stanovanja kao prediktorskom varijablom i postignućem učenika u prirodoslovlju (kriterijska varijabla)

	Nestandardizirani koeficijenti		Standardizirani koeficijenti	Sig.	Korelacija	
	B	SE	Beta		direktna	parcijalna
(Konstanta)	508,193	1,940		0,000		
Regija – Jadranska Hrvatska	-18,994	2,696	-0,111	0,000	-0,042	-0,097
Regija – Središnja i Istočna Hrvatska	-25,324	2,838	-0,141	0,000	-0,086	-0,123

$R^2=0,017$; $F=44,454$ ($p<0,001$)

Tablica 6.

Multipla regresija socioekonomskih indikatora i stanovanja u određenoj regiji (prediktori) i učeničkog rezultata iz prirodoslovlja (kriterij)

	Nestandardizirani koeficijenti		Standardizirani koeficijenti	Sig.	Korelacija	
	B	SE	Beta		direktna	parcijalna
(Konstanta)	459,051	4,962		0,000		
Najviši međunarodni socioekonomski indeks zanimanja	0,850	0,088	0,160	0,000	0,343	0,146
Indeks obiteljskih obrazovnih resursa	8,588	1,269	0,097	0,000	0,245	0,103
Indeks posjedovanja kulturnih dobara	7,499	1,395	0,088	0,000	0,312	0,082
Broj knjiga u kućanstvu: 11 - 25	13,294	3,145	0,073	0,000	-0,096	0,064
Broj knjiga u kućanstvu: 26 - 100	31,098	3,292	0,179	0,000	0,129	0,143
Broj knjiga u kućanstvu: više od 100	44,158	4,070	0,218	0,000	0,272	0,164
Prosječni mjesečni prihod kućanstva manji od 4 000 kn	-16,319	2,772	-0,086	0,000	-0,236	-0,090
Prosječni mjesečni prihod kućanstva veći od 10 000 kn	14,173	3,243	0,065	0,000	0,224	0,067
Prosječni mjesečni izdaci za obrazovanje 150-400 kn	-12,913	2,368	-0,076	0,000	-0,037	-0,083
Prosječni mjesečni izdaci za obrazovanje veći od 400 kn	-20,935	3,385	-0,086	0,000	-0,066	-0,094
Najviše obrazovanje roditelja – OŠ ili manje	-9,270	4,058	-0,033	0,022	-0,171	-0,035
Najviše obrazovanje roditelja – Viša škola ili više	-2,007	2,547	-0,012	0,431	0,179	-0,012
Regija – Jadranska Hrvatska	-16,667	2,550	-0,100	0,000	-0,047	-0,099
Regija – Središnja i Istočna Hrvatska	-8,976	2,733	-0,051	0,001	-0,078	-0,050

$R^2=0,237$; $F=95,233$ ($p<0,001$)

Varijabla stanovanja u određenoj regiji ostala je i nakon ubacivanja u regresijski

model s indikatorima socioekonomskog statusa (tablica 6.) statistički značajna, što

bi značilo da je nakon uzimanja u obzir utjecaja ostalih prediktora, regija iz koje učenici dolaze i dalje značajno povezana s uspjehom učenika, iako se njen utjecaj smanjio u usporedbi sa samostalnim modelom (tablica 5.). Standardizirani koeficijenti indikatora SES-a nisu se bitno promijenili (usporedi tablicu 4.), dok se udio protumačene varijance postignuća u prirodoslovlju ubacivanjem regije povećao za gotovo 1%. Regresijski modeli s varijablom stanovanja u određenoj regiji (tablice 5. i 6.) pokazuju da učenici koji obitavaju u Sjeverozapadnoj Hrvatskoj postižu bolje rezultate u prirodoslovlju od učenika u preostale dvije regije. Spomenuto smanjenje beta pondera vidljivo je u slučaju stanovanja u Središnjoj i Istočnoj Hrvatskoj u čijem su slučaju socioekonomski indikatori preuzeli veći dio utjecaja na postignuće učenika. Ovakav rezultat potvrđuje i nedavno provedeno istraživanje UNDP-a prema kojem županije Središnje i Istočne Hrvatske raspolažu prosječno najnižim kućanskim dohotkom, dok je najviši kućanski dohodak zabilježen u Istarskoj županiji i Gradu Zagrebu (Japac i Šućur, 2007.).¹⁴ Isto tako, Karaman Aksentijević i suradnici (2006.:29) ističu da ruralne regije imaju najniži životni standard i najnerazvijenije ljudske resurse, što dodatno potkrepljuju podatkom da je u tim regijama, osim slabe razvijenosti, niskih primanja, širenja siromaštva i malog udjela visoko obrazovanog stanovništva, zabilježen i statistički značajan ispodprosječni udio studenata.

Rezultati finalnog modela regresijske analize (tablica 6.) pokazuju značajnu povezanost indikatora SES-a i stanovanja u pojedinoj regiji s ispitnim rezultatom iz prirodoslovlja (tumače 24% varijance), no dodatna objašnjenja rezultata treba tražiti i u drugim mogućim faktorima koji bolje tumače postignuće učenika. S obzirom na

sastav pitanja u upitniku za učenike to bi mogli biti stavovi o prirodoslovlju i srodnim temama, indeksi motivacije, interesa za učenje prirodnih znanosti, ekološke osviještenosti koji su se, uz ostale, pokazali značajnim prediktorima u regresijskim modelima prikazanim u hrvatskom izvješću o rezultatima PISA istraživanja 2006. (Braš Roth i sur., 2008.). S druge strane, razlike u kognitivnim sposobnostima učenika te uloženi trud, koji nisu u fokusu ovog rada, vjerojatno još bolje tumače rezultat postignut u prirodoslovlju i općenito u drugim predmetima (usp. Deluca i Rosenbaum, 2001.).

* * *

Pri analizi podataka dobivenih PISA istraživanjem važno je imati na umu i nedostatke samog istraživanja. Iako je u PISA istraživanju vidljiv napor da se u obzir uzimaju metodološki problemi međunarodne usporedbe velikog razmjera te da se osigura kulturna nepristranost pitanja, neke dvojbe ipak su i dalje prisutne. Valjanost i pouzdanost konstruiranja pojedinih kompozitnih varijabli upitne su (Gorard i sur., 2008.), što se posebice može primijetiti na razini zemalja koje su sudjelovale u istraživanju te do određene mjere i na razini ukupnih rezultata. Neke od razloga treba potražiti u činjenici da, iako je namjera bila osigurati kulturnu nepristranost pitanja, doslovni prijevod je u mnogo slučajeva rezultirao nejasno konstruiranim pitanjima koja su ispitanicima bila nerazumljiva. Topping i suradnici (2003.) posebno ističu da odgovaranje na pitanja ispitanicima otežavaju specifična kulturna okruženja i njihova (društvena) percepcija »normalnosti«. Kada se u obzir uzmu i kulturne različitosti u odstupanjima od društveno poželjnih odgovora ili općenito vjerojatnosti davanja odgo-

¹⁴ Prema istom se istraživanju sve jadranske županije, osim Zadarske, nalaze u gornjem dijelu distribucije prema visini kućanskog dohotka (Japac i Šućur, 2007.).

vora na pitanja, baza podataka prikupljena istraživanjem poput PISA-e nema mehanizme kontrole te ovisi isključivo o ponderiranju podataka za svaku zemlju, što se opet vrši prema određenim varijablama koje nisu osjetljive na kulturne specifičnosti. Ova ograničenja mogućnosti odgovora mogla bi također potaknuti pitanja o skalarnim i psihometrijskim svojstvima dobivenih podataka i njihovoj primjenjivosti u statističkim analizama (Topping i sur., 2003.).

Još jedan metodološki nedostatak predstavlja uzorak sastavljen od isključivo petnaestogodišnjih učenika. Iako je odabir upravo te starosti objašnjen PISA istraživanjem, ipak je moguće da utječe na ispitne rezultate jer se učenici u različitim zemljama nalaze na različitom stupnju obrazovanja, a ne postoji kontrolni mehanizam »količine« i razine obrađenog gradiva. Ipak, kada se promatra hrvatski uzorak, važno je naglasiti da je PISA istraživanje provedeno na konzistentan način u cijeloj Hrvatskoj, a pretpostavka je da se hrvatski petnaestogodišnjaci međusobno ne razlikuju značajno prema stupnju razvoja i postignutom stupnju obrazovanja zbog jedinstvenog obrazovnog sustava.

Uz navedeno, stručnjaci PISA istraživanja svakako bi trebali ispitati mogućnosti kreiranja i drugih indeksa SES-a. To se posebice odnosi na već navedeni potencijalni indeks mjesečnih izdataka za obrazovanje s obzirom na mjesečne prihode kućanstva koji bi uvelike doprinio razumijevanju obiteljskog okruženja učenika i motivacije roditelja za ulaganje u obrazovanje vlastitog djeteta, a što bi se na kraju moglo odraziti i na uspjeh u školi.

ZAKLJUČAK

Analiza podataka prikupljenih PISA istraživanjem potvrdila je i u Hrvatskoj značajnu povezanost indikatora socioekonomskog statusa i postignuća učenika,

odnosno njihovog uspjeha na ispitu iz prirodoslovne pismenosti. Prediktorski model sastavljen od sedam indeksa i varijabli SES-a te varijable stanovanja u određenoj hrvatskoj regiji protumačio je 24% varijance postignuća u prirodoslovlju, no čak i bez empirijskih dokaza opravdano je pretpostaviti da učenikovo okruženje predstavlja vrlo utjecajan faktor na njegovo/njezino obrazovno postignuće (Burstein i sur., 1980.). Indikatori obiteljskog okruženja reflektiraju razlike među učenicima, a posredno opisuju i značajke šire zajednice preko agregacije učenika koji potječu iz sličnih okruženja.

Socioekonomski status u Hrvatskoj posredno ili neposredno utječe na svaku etapu obrazovanja pojedinca. Bez obzira na »besplatno« školovanje (na osnovnoškolskoj i srednjoškolskoj razini) socioekonomski status je i dalje povezan s mogućnostima izbora škole, školskog programa i daljnjeg profiliranja učenika. Negativan primjer koji bi Hrvatska svakako trebala izbjeći jest njemački paralelni sustav različitih školskih programa gdje upis u određene programe isključivo ovisi o socioekonomskom statusu obitelji (Domović, 2005.). Uzore treba tražiti u finskom modelu obrazovanja koji omogućava jednakost šansi za sve učenike iz različitih obiteljskih okruženja. Na to također upućuju Ianelli i Smyth (2008.) ističući da je utjecaj socijalne pozadine na obrazovanje manje vidljiv u Švedskoj i Finskoj - zemljama sa sveobuhvatnim obrazovnim sustavima usmjerenima na cjeloživotno obrazovanje, a izraženiji u zemljama s diferenciranim sustavima obrazovanja (Mađarska, Rumunjska i Slovačka), dok u zemljama Istočne Europe socijalna različitost nije ograničena samo na obrazovni sustav, već je primjetna na ukupnoj državnoj razini.

U nekim svjetskim obrazovnim sustavima postoje mehanizmi koji minimaliziraju ili barem ublažavaju utjecaje SES-a na obrazovna postignuća. To su primjerice sustavi s ranim praćenjem učenika prema

njihovim sposobnostima, s visokim stupnjem naknada za plaćanje školarina i/ili sa sporazumnim diferencijalnim lokalnim financiranjem obrazovnih ustanova (The Royal Society, 2008.). Prema tome, škole bi trebale biti u mogućnosti osigurati učenicima ravnopravne uvjete za nastavu i rad, primjerena tehnička pomagala, opremljene knjižnice, te zajedno s lokalnim vlastima i institucijama razvijati relevantne programe za smanjenje nejednakosti šansi i kulturnih ili drugih različitosti.

Iako je možda nerealno očekivati da će uskoro u Hrvatskoj visokokvalitetno obrazovanje biti besplatno i raspoloživo svoj djeci, što je prema Duman (2008.) jedan od glavnih faktora za smanjenje utjecaja obiteljskog podrijetla na obrazovanje, škole s ograničenim financijskim resursima također imaju mehanizme umanjivanja utjecaja obiteljskog SES-a na obrazovni uspjeh. To se može postići kreiranjem manjih škola i manjih razreda, uvođenjem obrazovanja u ranom djetinjstvu, dodatne i dopunske nastave, ljetnih škola te zapošljavanjem kvalificiranog nastavnog osoblja (Sirin, 2005.).

U kontekstu smanjenja nejednakosti i društvenih različitosti mogu se (i trebaju) gledati i rezultati prikupljeni velikim međunarodnim istraživanjima. Iako postoje značajna ograničenja i kritike, u literaturi se često ističu pozitivne strane ovakvih istraživanja. Tako npr. Willms i Somers (2001.) ističu da međunarodna istraživanja ovog tipa mogu biti korisna zemljama sudionicama budući da im omogućavaju usporedbu s drugim zemljama sličnih društvenih i ekonomskih prilika. Takve usporedbe »(...) mogu biti korisne ukoliko izazovu dijalog o učinkovitosti školskog sustava i o važnosti strateških investicija u obrazovanje. Međutim, glavna vrijednost međunarodnih istraživanja može se izvesti iz detaljne analize unutar svake zemlje, analize koja bi otkrila jake i slabe strane, odredila izraženost nejednakosti među

različitim grupama i razotkrila učinke pojedinih politika i praksi na koje se može djelovati putem različitih socijalnih politika« (Willms i Somers, 2001.:437). Takva analiza u Hrvatskoj još nije realizirana niti je poznato je li uopće u planu. Državna i lokalna vlast trebale bi pratiti rezultate svih područja procjene s obzirom na učenički socioekonomski status. Isto tako, potrebno je na institucionalnoj razini razvijati mehanizme i prakse usmjerene na smanjenje nejednakosti u ispitnim rezultatima s obzirom na SES imajući u vidu i ravnomjerno regionalno ulaganje u obrazovanje.

Naposljetku, svakako bi trebalo postaviti analizirati podatke međunarodnih istraživanja u kojima Hrvatska sudjeluje, s namjerom potencijalne implementacije promjena i senzibilizacije hrvatskog obrazovnog sustava. Adekvatna stručna i znanstvena analiza podataka PISA istraživanja (i drugih sličnih projekata) omogućila bi, između ostalog, kreiranje dinamičnog sustava praćenja obrazovnih postignuća koji bi trebao biti transparentan i kontinuiran, u skladu s napretkom tehnologije i ekonomskim razvojem, te usmjeren na reviziju i prilagodbu kurikulumu usmjerenih na područja obrazovanja koja treba »ojačati«, što bi na kraju opravdalo i državna ulaganja u takve projekte.

LITERATURA

- Attewell, P., & Battle, J. (1999). Home computers and school performance. *The Information Society*, 15(1), 1-10. doi:10.1080/019722499128628
- Arnett, S. (2004). National variation in the effects of socioeconomic status on student learning. *Conference Papers - American Sociological Association, 2004 Annual Meeting, San Francisco*, 1-16.
- Botrić, V. (2007). Regional labour market differences in Croatia: Evidence from the 2000-2005 labour force survey data. *Privredna kretanja i ekonomska politika*, 17(113), 27-51.
- Braš Roth, M., Gregurović, M., Markočić Dekanić, A., & Markuš, M. (2008). *PISA 2006. Prirodo-*

- slovne kompetencije za život. Zagreb: Nacionalni centar za vanjsko vrednovanje obrazovanja.
- Burstein, L., Fischer, K. B., & Miller, M. D. (1980). The multilevel effects of background on science achievement: A cross-national comparison. *Sociology of Education*, 53(4), 215-225. doi:10.2307/2112530
- Davies, S. (1995). Leaps of faith: Shifting currents in critical sociology of education. *American Journal of Sociology*, 100(6), 1448-1478. doi:10.1086/230668
- Deluca, S., & Rosenbaum, J. E. (2001). Individual agency and the life course: Do low-SES students get less long-term payoff for their school efforts? *Sociological Focus*, 34(4), 357-376.
- DiMaggio, P. (1982). Cultural capital and school success: The impact of status culture participation on the grades of U.S. high school students. *American Sociological Review*, 47(2), 189-201. doi:10.2307/2094962
- Domović, V., & Godler, Z. (2005). Procjena učinkovitosti obrazovnih sustava na osnovi učeničkih dostignuća: Usporedba Finska - Njemačka. *Društvena istraživanja*, 14(3), 439-458.
- Driessen, G. W. J. M. (2001). Ethnicity, forms of capital and educational achievement. *International Review of Education*, 47(6), 513-538. doi:10.1023/A:1013132009177
- Državni zavod za statistiku Republike Hrvatske (2007). *Statistički ljetopis 2007*. Posjećeno 28. 4. 2010. na mrežnoj stranici: www.dzs.hr
- Državni zavod za statistiku Republike Hrvatske (2009). *Bruto domaći proizvod za Republiku Hrvatsku, prostorne jedinice za statistiku 2. razine i županije od 2000. do 2006*. Priopćenje 3. srpnja 2009., br. 12.1.5. Posjećeno 17. 4. 2010. na mrežnoj stranici: www.dzs.hr.
- Duman, A. (2008). Obrazovanje i nejednakost dohotka u Turskoj: je li školovanje važno? *Financijska teorija i praksa*, 32(3), 373-389.
- Fahey, T., Whelan, C. T., & Maître, B. (2004). *Quality of life in Europe: First European quality of life survey 2003*. Luxembourg: Office for Official Publications of the European Communities.
- Fram, M. S., Miller-Cribbs, J. E., & Van Horn, L. (2007). Poverty, race, and the contexts of achievement: Examining educational experiences of children in the U.S. South. *Social Work*, 52(4), 309-319.
- Ganzeboom, H. B. G., De Graaf, P. M., & Treiman, D. J. (1992). A standard international socioeconomic index of occupational status. *Social Science Research*, 21(1), 1-56. doi:10.1016/0049-089X(92)90017-B
- Ganzeboom, H. B. G., & Treiman, D. J. (1996). Internationally comparable measures of occupational status for the 1988 International Standard Classification of Occupations. *Social Science Research*, 25(3), 201-239. doi:10.1006/ssre.1996.0010
- Gorard, S., See, B. H., & Smith, E. (2008). The impact of SES on participation and attainment in science: An analysis of available data. In Royal Society (Ed.), *Exploring the relationship between socio-economic status and participation and attainment in science education* (pp. 22-29). Posjećeno 28. 3. 2010. na mrežnoj stranici: www.royalsociety.org/education
- Hatcher, R. (1998). Class differentiation in education: Rational choices? *British Journal of Sociology of Education*, 19(1), 5-24. doi:10.1080/0142569980190101
- Heyneman, S. P. (1976). Influences on academic achievement: A comparison of results from Uganda and more industrialized societies. *Sociology of Education*, 49(3), 200-211. doi:10.2307/2112231
- Iannelli, C., & Smyth, E. (2008). Mapping gender and social background differences in education and youth transitions across Europe. *Journal of Youth Studies*, 11(2), 213-232. doi:10.1080/13676260701863421
- Japec, L., & Šučur, Z. (ur.). (2007). *Kvaliteta života u Hrvatskoj: regionalne nejednakosti*. Zagreb: Program Ujedinjenih naroda za razvoj (UNDP) u Hrvatskoj.
- Karaman Aksentijević, N., Bogović, N. D., & Ježić, Z. (2006). Education, poverty and income inequality in the Republic of Croatia. *Zbornik radova Ekonomskog fakulteta u Rijeci: časopis za ekonomsku teoriju i praksu*, 24(1), 19-37.
- Lovrinčević, Ž., Marić, Z., & Rajh, E. (2005). Kako optimalno regionalizirati Hrvatsku? *Ekonomski pregled*, 56(12), 1109-1160.
- Magno, C. (2009). Demonstrating the difference between classical test theory and item response theory using derived test data. *The International Journal of Educational and Psychological Assessment*, 1(1), 1-11.
- Marks, G. N. (2007). Cultural capital and inequalities in education: Some cross-national evidence. *Conference Papers - American Sociological Association, 2007 Annual Meeting*, 1-30.
- Matějů, P., & Peschar, J. L. (1989). Family background and educational attainment in Czechoslovakia and the Netherlands. *International Journal of Sociology*, 19(3), 72-100.
- Matković, T. (2010). Obrazovanje roditelja, materijalni status i rano napuštanje školovanja u Hrvatskoj: trendovi u proteklom desetljeću. *Društvena istraživanja*, 19(5).

- Merola, S. S. (2005). The problem of measuring SES on educational assessments. *Conference Papers - American Sociological Association, 2005 Annual Meeting*, 1-20.
- Muis, K. R., Winne, P. H., & Edwards, O. V. (2009). Modern psychometrics for assessing achievement goal orientation: A Rasch analysis. *British Journal of Educational Psychology*, 79(3), 547-576. doi:10.1348/000709908X383472
- Nestić, D. (2002). Ekonomska nejednakost u Hrvatskoj 1998. manja od očekivanja. *Ekonomski pregled*, 53(11-12), 1109-1150.
- Organisation for Economic Co-operation and Development (2007). *PISA 2006 Science Competencies for Tomorrow's World, volume 1: Analysis*. Paris: OECD.
- Organisation for Economic Co-operation and Development (2009). *PISA 2006 Technical Report*. Posjećeno 22. 4. 2010. na mrežnoj stranici: <http://www.oecd.org/dataoecd/0/47/42025182.pdf>
- Okpala, C. O., Okpala, A. O., & Smith, F. E. (2001). Parental involvement, instructional expenditures, family socioeconomic attributes, and student achievement. *The Journal of Educational Research*, 95(2), 110-115. doi:10.1080/00220670109596579
- Pavić, Ž., & Vukelić, K. (2009). Socijalno podrijetlo i obrazovne nejednakosti: istraživanje na primjeru osječkih studenata i srednjoškolaca. *Revija za sociologiju*, 40(1-2), 53-70.
- Rumberger, R. W., & Palardy, G. J. (2005). Does segregation still matter? The impact of student composition on academic achievement in high school. *Teachers College Record*, 107(9), 1999-2045. doi:10.1111/j.1467-9620.2005.00583.x
- Sewell, W. H., Haller, A. O., & Ohlendorf, G. W. (1970). The educational and early occupational status attainment process: Replication and revision. *American Sociological Review*, 35(6), 1014-1027. doi:10.2307/2093379
- Sewell, W. H., & Shah, V. P. (1967). Socioeconomic status, intelligence, and the attainment of higher education. *Sociology of Education*, 40(1), 1-23. doi:10.2307/2112184
- Sirin, S. R. (2005). Socioeconomic status and academic achievement: A meta-analytic review of research. *Review of Educational Research*, 75(3), 417-453. doi:10.3102/00346543075003417
- Strakova, J. (2007). The impact of the structure of the education system on the development of the educational inequalities in the Czech Republic. *Czech Sociological Review*, 43(3), 589-610.
- Šundalić, A. (2006). Osiromašivanje i nerazvijenost – Slavonija i Baranja u očima njezinih stanovnika. *Socijalna ekologija*, 15(1-2), 125-143.
- Šundalić, A. (2009). Ruralni prostor i društvena struktura - novi identiteti Slavonije i Baranje. *Ekonomski vjesnik*, 22(1), 11-22.
- The Royal Society (2008). *Exploring the relationship between socio-economic status and participation and attainment in science education. SES and Science Education Report*. Posjećeno 28. 3. 2010. na mrežnoj stranici: www.royalsociety.org/education.
- Thoreson, A. (2004). Trends in SES effects on group differences in academic achievement. *Conference Papers - American Sociological Association, 2004 Annual Meeting*, 1-43.
- Thorpe, G. (2006). Multilevel analysis of PISA 2000 reading results for the United Kingdom using pupil scale variables. *School Effectiveness and School Improvement*, 17(1), 33-62. doi:10.1080/09243450500264473
- Topping, K., Valtin, R., Roller, C., Brozo, W., & Lourdes, M. D. (2003). *Policy and practice implications of the Program for International Student Assessment (PISA) 2000. Report of the International Reading Association PISA Task Force*. Newark: International Reading Association.
- Willms, J. D. (2006). Variation in socioeconomic gradients among cantons in French and Italian-speaking Switzerland: Findings from the OECD PISA. *Educational Research and Evaluation*, 12(2), 129-154. doi:10.1080/13803610600587008
- Willms, J. D., & Somers, M.-A. (2001). Family, classroom, and school effects on children's educational outcomes in Latin America. *School Effectiveness and School Improvement*, 12(4), 409-445. doi:10.1076/sesi.12.4.409.3445
- Yang, Y. (2003). Dimensions of socio-economic status and their relationship to mathematics and science achievement at individual and collective levels. *Scandinavian Journal of Educational Research*, 47(1), 21-41. doi:10.1080/003138303080609
- Yildirim, U., & Eryılmaz, A. (1999). Effects of gender, cognitive development and socioeconomic status on physics achievement. *Hacettepe Üniversitesi Eğitim Fakültesi Dergisi*, 15(1), 121-126.
- Young, D. J. (1995). Effect of the science learning environment on science achievement: A comparison of 12 countries from the IEA Second International Study. *Educational Research and Evaluation*, 1(2), 129-158. doi:10.1080/1380361950010202
- Young, D. J., & Fraser, B. J. (1993). Socio-economic and gender effects on science achievement: An Australian perspective. *School Effectiveness and School Improvement*, 4(4), 265-289. doi:10.1080/0924345930040403

Summary

EFFECT OF SOCIOECONOMIC STATUS ON STUDENTS' EDUCATIONAL ACHIEVEMENT: THE EXAMPLE OF PISA STUDY, CROATIA 2006

Margareta Gregurović, Simona Kuti

*Institute for Migration and Ethnic Studies
Zagreb, Croatia*

One's socio-economic status affects almost every aspect of his/hers life, including education. The main objective of this paper is to determine the relationship between familial socioeconomic status and students' educational achievement. The paper is based on the OECD – PISA international study carried out in Croatia in 2006 on the sample of 5 209 15-year-old students involved in secondary education. Students' results in scientific literacy, as well as variables and indices constructed by OECD, were used in analyses. The distributions of selected variables linked to socio-economic status definition, such as parental education, monthly household income, educational expenses and home educational resources are presented, as well as their regional differences. Multiple regression analysis proved the relationship between socioeconomic factors and students' science test accomplishment. Regression model which includes three indices (Highest International Socioeconomic Index of Occupational Status, Index of home educational resources and Index of cultural possessions) and four variables (average monthly household income, average monthly educational expenses, household book number and highest educational status of parents) explain 23 per cent of the total variance of students' achievement in scientific literacy. The second regression model with the region of residence additionally contributes to variance explanation by 1 per cent, indicating significant relation between living in specific Croatian region and science achievement. The main conclusion of this paper is that socio-economic status (along with the region of residence) represents a significant predictor of the educational achievement, and that it is relevant in analyses and interpretations of PISA results, even though Croatia could use an adaptation of PISA indices in order to trustworthily represent the data. It is advisable to continuously analyse the test results and, besides some general indicators of educational success, such as educational system, teacher qualifications and school infrastructure, also to consider the effect of students' socioeconomic status.

Key words: socioeconomic status, educational achievement, OECD PISA, Croatia, Croatian regions.